



**Makale / Research Paper**

**Derin Öğrenme ile Beton Yapılarda Otonom Çatlak Tespiti**

**Tarkan KARAÇAY<sup>1a</sup>**

Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, İnşaat Mühendisliği Bölümü.  
Eskişehir/TÜRKİYE  
[mail.tarkankaracay@gmail.com](mailto:mail.tarkankaracay@gmail.com)

**Received/Geliş:** 17.08.2021

**Accepted/Kabul:** 22.10.2021

**Öz:** Bu çalışma beton yapılarda çatlak tespitinin bilgisayarlı görü ve derin öğrenme kullanılarak otonom gerçekleştirilmesi konusundadır. Çatlakların hızlı ve başarılı şekilde tespit edilmesi yapısal hasar tespitinin erken ve etkili yapılabilmesi için oldukça önemlidir. Bu kapsamda çevrim içi kaynaklardan elde edilen, içerisinde çatlak fotoğrafları bulunan 3 farklı veri seti ve içerisinde çatlak fotoğrafı bulunmayan farklı yapıların farklı bölgelerine ait fotoğraflar bulunan bir veri seti kullanılmıştır. Derin öğrenme mimarisinin eğitimi ve testi için veri setlerinin farklı kombinasyonlarda kullanımı ile elde edilen sonuçlar tartışılmıştır. Derin öğrenme mimarisi olarak görüntü bölütlemesi (image segmentation) için tasarlanmış olan U-Net kullanılmıştır. Elde edilen bulgular betonarme yapılarda çatlak tespiti için eğitilen evrişimli sinir ağlarında eğitim verisi içerisinde yapıların farklı bölgelerine ait çatlak içermeyen fotoğrafların kullanılması ile çatlak tespiti konusundaki başarı oranının arttığını göstermiştir. Ayrıca evrişimli sinir ağının eğitimi ve testi için birbirinden farklı veri setlerinin kullanılması ile elde edilen sonuçlar U-Net mimarisinin gerçek dünyadaki çatlak tespit problemlerinde kullanılabilir olduğu konusunda ciddi bir öngörü kazandırmıştır. Yapılan bu çalışmanın yapısal çatlak tespiti konusunda araştırma yapmak veya proje geliştirmek isteyen araştırmacılar için faydalı olması ve araştırmacıların yararlanabilecekleri noktaları tanıtması umulmaktadır.

**Anahtar Kelimeler:** Yapay zekâ; derin öğrenme; çatlak tespiti; yapısal hasar tespiti; yapı mühendisliği.

**Autonomous Crack Detection in Concrete Structures with Deep Learning**

**Abstract:** This study is about autonomous crack detection in concrete structures using computer vision and deep learning. Fast and successful detection of cracks is very important for early and effective detection of structural damage. In this context, 3 different data sets obtained from the online sources with crack photos and a data set with photos of different parts of different structures without crack photos were used. The results obtained by using different combinations of datasets for training and testing of deep learning architecture are discussed. U-Net, designed for image segmentation, was used as a deep learning architecture. The findings showed that the success rate of crack detection increased with the use of crack-free photographs of different parts of the structures in the training data in convolutional neural networks trained for crack detection in reinforced concrete structures. In addition, the results obtained by using different data sets for the training and testing of the convolutional neural network have given a serious insight that the U-Net architecture can be used in real-world crack detection problems. It is hoped that this study will be useful for researchers who want to research or develop projects on structural crack detection and introduce the points that researchers can benefit from.

**Keywords:** Artificial intelligence; deep learning; crack detection; structural damage detection; structural engineering.

## 1. Giriş

Yapay zekâ ve otomasyon son yılların en çok ilgi gören konularındandır. Yüksek hacimli verilerin doğru ve güvenilir şekilde yorumlanmak istenmesi, kısıtlı kaynakların doğru kullanımının hedeflenmesi, girdiler ile çıktılar arasındaki ilişkilerin geleneksel yöntemler (regresyon vb.) ile bulunmasının kimi zaman oldukça zor olması, insan kusurlarından arındırılmış sistemlerin daha kullanışlı olacağı düşünülmesi vb. nedenlerle bu kavramlar gittikçe daha da önem kazanmaktadır.

Yapay zekâ ve otomasyon kavramlarının gün geçtikçe yaygınlaşması ile inşaat mühendisliğinde de bu konularda yapılan çalışmalar oldukça artmıştır. Örneğin; Karaçay ve Özbaşaran tarafından kaleme alınan yakın zamandaki bir çalışmada yapı mühendisliği ile ilgili 141 adet Türkçe yapay zekâ çalışması bulunmuştur [1].

Yapılarda ve yapı elemanlarında oluşan yüzeysel kusurlar yapı sağlığının izlenebilmesi için kritik öneme sahiptir. Bu yüzeysel kusurların başında çatlaklar gelmektedir. Çatlakların tespiti için genellikle insan uzmanlardan yararlanılmaktadır. Bu uzun zamandır süre gelen bir çalışma şekli olsa da günümüzde yapay zekâdan yararlanılarak otonom bir çatlak tespiti sistemine ihtiyaç olduğu düşünülmektedir. Bunun nedenleri şöyle sıralanabilir:

- Devlet kurumları, köprü, tünel, baraj vb. nispeten daha önemli binalarda periyodik denetimin masraflı ve zaman alıcı olması [2], [3].
- Köprülerde ve tünellerde manuel hasar tespit çalışması yapılabilmesi için onları kapatmanın gerekmesi [4].
- Kalifiye denetleyicinin (uzman) her zaman erişilemeyebilir olması.
- Geleneksel görsel değerlendirmede uzman kişilerin becerilerine bağlı olarak hata yapma ihtimalinin olması<sup>1</sup>.
- Bazı yapıların belirlenen kullanım ömürlerinden daha uzun süredir kullanılıyor olması [5].
- İnsan uzmanın ve ekibinin hayatını tehlikeye atabilecek durumlarda dahi denetim yapılma gereksiniminin olması [6]. (Fiziksel olarak erişimin zor olduğu yerler, karanlık ve ıslak yerler, yaralanma ya da ölüm tehlikesinin olduğu yeraltı yapıları vb. bölgeler kimi zaman insanların denetim yapması için oldukça zor veya imkânsız koşullar barındırabilir.)
- Afet sonrası hızlı hasar tespiti için öngörü oluşturulması.
- Zaman tasarrufu yapılabilmesi. (Robotlar ve insansız hava araçlarının yapacağı denetimler sırasında yapay zekâ ile görüntülerden bilgi çıkarılması sağlanabilir ve bilgiler ile birlikte görüntü denetimci kişiye ulaştırılabilir. Görüntülerin işleme kısmı insan elinden çıkacağı için zamandan tasarruf edilebilmesi sağlanacaktır.)

Bu çalışma yapay zekâ ve otomasyon konularının beton yapılardaki çatlakların tespitinde kullanılması konusundadır. Bu kapsamda bilgisayarlı görü ve derin öğrenmeden yararlanılmıştır. Çalışmada evrişimli sinir ağı (convolutional neural network) (CNN) olan U-Net mimarisi kullanılmıştır. Çalışmanın bulunan önceki çalışmalardan farkları şöyle sıralanabilir:

<sup>1</sup> ImageNet veri seti üzerinde yapılan araştırmalar yapay zekânın insana göre fotoğrafları daha iyi sınıflandırabildiğini düşündürmektedir. Örneğin bir çalışmada [20] insanın sınıflandırma hatası yaklaşık %5.1 bulunmuştur. Aynı veri seti üzerinde yapılmış diğer bir araştırmada ise [21] yapay zekâ %3.57 hata yapmıştır. Bu sonuçlar yapay zekânın bilgisayarlı görü uygulamalarında insandan daha üstün olduğu anlamına gelmese de sonuçların bir öngörü sunduğu düşünülmektedir.

- 3 farklı veri seti kullanılmış olup bunların çeşitli kombinasyonları sonucunda elde edilen sonuçlar sunulmuştur ve yapılan uygulamanın gerçek dünya için uygulanabilir olduğu konusunda daha net ve açık sonuçlar sunulmuştur.
- Yapılan testlerden bazılarında eğitim için ayrılmış veri seti içerisine çatlak bulunmayan fakat oldukça gürültülü 1199 farklı fotoğraf eklenmiştir. Sonuçların değişimi incelenmiştir.

## 2. Literatür Özeti

Yapılan kaynak taraması sonucunda yapısal çatlakların evrişimli sinir ağları ile tespiti konusunda yapılmış olan bazı çalışmalar bulunmuştur.


Cha vd. 2017 senesinde görüntü işleme ve evrişimli sinir ağlarından yararlanarak beton çatlakların tespit edilmesi konusunda çalışmışlardır. Kenar detektörlerinin (edge detector) gürültüden ve ışıklandırma şiddetinden etkilenebileceğini söylemişlerdir. Görüntüler bir şekilde gürültüden arındırılrsa dahi gerçek dünyada görüntü verilerinin farklılıklarından kaynaklı kenar detektörlerinin kullanılması yerine evrişimli sinir ağlarından yararlanmışlardır. Kullandıkları veri setindeki görüntülere çeşitli görüntü işleme teknikleri (döndürme vb.) uygulamışlar ve kendi ürettikleri bir evrişimli sinir ağı mimarisi ile %98.22 ve %97.95 doğruluk oranlarına ulaşmayı başarmışlardır [5]. Modarres vd. 2018 yılında yayımlanmış çalışmalarında bir evrişimli sinir ağı mimarisi tasarladıklarını ve çeşitli yüzey kusurlarının tespitlerinin yapılması konusunda çalıştıklarını belirtmişlerdir. Eğitim ve test için ayırdıkları veri setinde test için sadece gürültülü fotoğrafların kullanıldığını belirtmişlerdir [6]. Dorafshan vd.'nin 2018 yılında yayımlanmış oldukları çalışma, kenar detektörlerinin ve derin evrişimli sinir ağlarının (deep convolutional neural network) başarı karşılaştırmasının yapılması konusundadır. 19 yüksek kaliteli fotoğrafı 3420 alt fotoğrafa ayırdıklarını ve test yaptıklarını belirtmişlerdir. Elde edilen sonuçlar derin evrişimli sinir ağı mimarilerinin kenar detektörlerine göre çatlak tespitinde daha iyi sonuçlar verdiği yönündedir [7]. Özgenel ve Sorguç'un 2018 yılında sundukları çalışma farklı evrişimli sinir ağı mimarilerinin, fotoğrafların çatlaklı veya çatlaksız olarak sınıflandırılması konusunda başarılarının karşılaştırılması üzerinedir [8]. Bu kapsamda araştırmacılar kendi veri setlerini oluşturmuş ve yayımlanmışlardır [9]. Wang vd. aynı sene tarihi yapılarla ilgili bir hasar tespit çalışması sunmuşlardır. Çalışma AlexNet ve GoogleNet isimli iki evrişimli sinir ağı mimarisinin geliştirilmiş hallerini sunmaktadır [10]. Liu vd. 2019'da U-Net isimli bu çalışmada da kullanılan mimariyi kullanarak hasar tespiti üzerinde çalışmışlardır. Elde ettikleri sonuçları FCN isimli mimari kullanılmış olan diğer bir çalışma ile karşılaştırmışlardır [4]. Li ve Zhao aynı yıl yapısal çatlakların tespiti için bir çalışma yayımlamıştır. Bu çalışmanın önceki satırlarda bahsedilmiş çalışmalara göre öne çıkan özelliği eğitilmiş evrişimli sinir ağı modelinin mobil uygulama haline getirilmiş olmasıdır. Kullanılan evrişimli sinir ağı mimarisi AlexNet'in değiştirilmiş bir versiyonudur [11].

Dung ve Anh'in 2019'da yayımlanmış oldukları çalışma çatlakların sınıflandırılması konusundadır. Japonya ve Amerika'da yapılan muayeneler sonucunda çöken köprülerin %46'sının çökmeden önce belirlenebileceğini söyleyen yazarlar bunun için bir bakım stratejisine ihtiyaç olduğunu bunun için evrişimli sinir ağlarından yararlandıklarını belirtmişlerdir [12]. Li vd.'nin aynı sene yayımlanmış olan çalışmaları yapılarıdaki 4 farklı yüzey kusurunun otonom bir şekilde bulunması üzerinedir. Bunun için SegNet ve FCN mimarileri kullanmışlardır. Karşılaştırmalı olarak elde ettikleri başarıları sunmuşlardır [13]. Ren vd. bir sene sonra 2020'de betondaki çatlakların tespiti için CrackSegNet isimli bir mimari oluşturduklarını belirtmişlerdir. Oluşturdukları mimarinin karşılaştırdıkları diğer mimarilere göre daha iyi sonuçlar verdiğini söylemişlerdir [14]. Aynı sene Li vd. tarafından yayımlanan diğer bir çalışma ise asfaltta oluşan çatlakların tespiti üzerinedir. Araştırmacılar oluşan çatlakları 6 farklı sınıfa ayırmışlar ve bunların tespiti konusunda çalışmışlardır [15].

### 3. Metot

#### 3.1. Veri Setinin Elde Edilmesi

Çalışma için gereken 4 farklı veri seti 2 farklı kaynaktan elde edilmiştir. Bu kaynaklardan birincisi Özgenel'in sunmuş olduğu çatlak bölütlemesi (crack segmentation) için veri setidir [16]. Veri seti  $2448 \times 3264$ ,  $3024 \times 4032$ ,  $4032 \times 3024$  piksel boyutlarında 458 tane fotoğraf ve fotoğraflarla eşleşen aynı sayıda maskelenmiş görüntü bulundurmaktadır. Veri setine ait bir görüntü Şekil 1'de verilmiştir. Şekilde üst sıradaki imgeler çekilen çatlak fotoğraflarına aittir. Alt sıradaki imgeler çatlak fotoğraflarının maskelenmiş (etiketlenmiş) halleridir. Bu veri setinden ilerleyen paragraflarda "Özgenel veri seti" ismiyle bahsedilecektir.



Şekil 1. Özgenel'in Sunmuş Olduğu Veri Setine Ait Örnekler


Çalışmada kullanılan diğer bir kaynak kaggle.com adresinden indirilmiştir [17]. Kaynak, içerisinde beton yapıların çatlak fotoğraflarını ve maskelenmiş hallerini bulunduran 2 veri seti ve asfaltlarda oluşan çatlakların fotoğraflarını ve maskelenmiş hallerini içeren veri setleri bulunmaktadır. Ayrıca veri seti içerisinde çatlak içermeyen, yapıların farklı bölgelerine ait oldukça gürültülü fotoğraflar bulunan bir veri seti daha vardır. Veri setlerindeki tüm fotoğraflar  $448 \times 448$  piksel boyutlarındadır.

İndirilen kaynaktaki veri setlerinden ilki hakkında çalışmanın ilerleyen kısmında "Rissbilder veri seti", diğeri için "Volker veri seti" olarak bahsedilecektir. Ayrıca içerisinde çatlak bulundurmayan fotoğrafları içeren veri setinden bu çalışmada "Non-Crack veri seti" olarak bahsedilecektir. Bu veri setlerinin yayımlandığı yazılara ulaşılammıştır. Veri setlerinden Rissbilder ve Volker veri seti olarak bahsedilmesinin nedeni indirilen kaynaktaki ilgili veri setlerinin bu isimleri taşıyan dosya adlarına sahip olmasındandır. İçerisinde çatlak fotoğrafı içermeyen veri seti için Non-Crack veri seti denmesi de aynı sebeptendir.

Bu veri setlerinden 4'er tane rastgele fotoğraf ve maskelenmiş hali seçilerek Şekil 2, Şekil 3 ve Şekil 4'te sunulmuştur.



Şekil 2. Rissbilder Veri Setine Ait Örnekler



Şekil 3. Volker Veri Setine Ait Örnekler



Şekil 4. Non-Crack Veri Setine (İçerisinde Çatlak İçermeyen Gürültülü Fotoğrafların Olduğu Veri Seti) Ait Örnekler

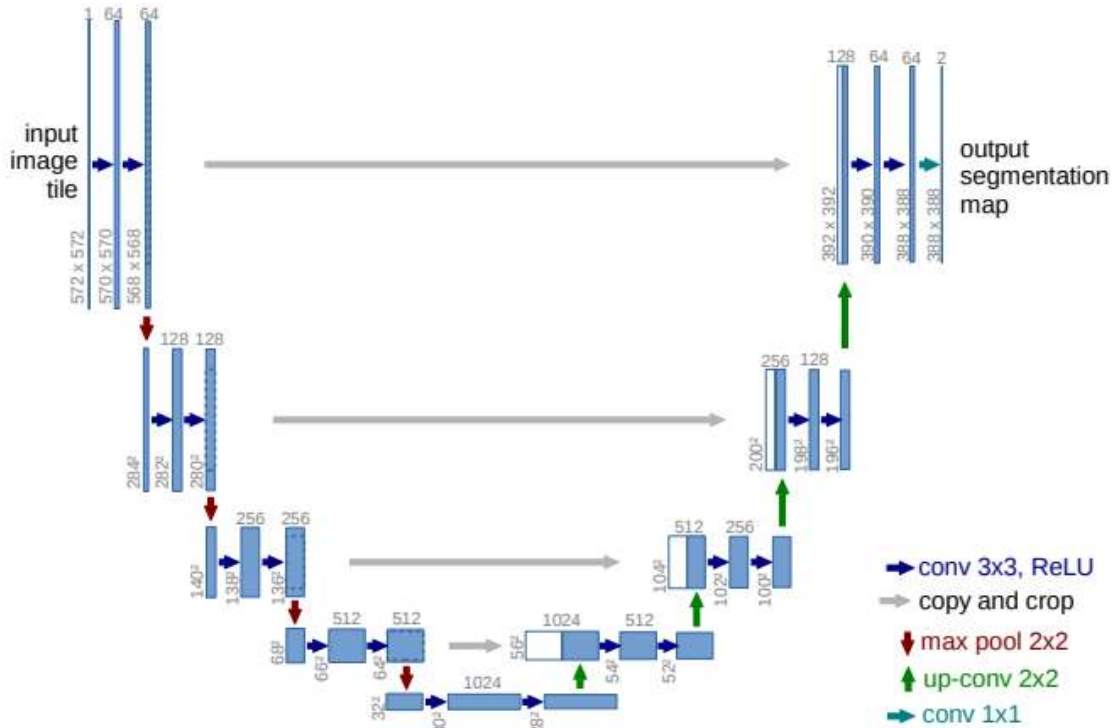
### 3.2. U-Net Derin Öğrenme Mimarisi

Bu çalışmada U-Net evrişimli sinir ağı mimarisi kullanılmıştır. U-Net Ronneberger vd. tarafından geliştirilmiş bir mimaridir [18]. Biomedikal imgelerin bölütlemesi için geliştirilmiş olsa da sonrasında farklı alanlardaki araştırmacılar tarafından da tercih edilmeye başlanmıştır. U-Net'i önceki evrişimli sinir ağı mimarilerinden ayıran en farklı özellik az veri setiyle dahi çok iyi sonuçlar verebilmesidir. Yazarlar bunu şu sözler ile ifade etmişlerdir:

*“Derin ağların başarılı eğitiminin binlerce açıklamalı (etiketlenmiş) eğitim örneğini gerektirdiği konusunda büyük bir kabul var. Bu yazıda, mevcut açıklamalı (etiketli) örnekleri daha verimli kullanmak için veri artırmanın güçlü kullanımına dayanan bir ağ ve eğitim stratejisi sunuyoruz.”*

U-Net mimarisi Şekil 5'te görülmektedir. Şekildeki mavi kutular çok kanallı bir özellik haritasına karşılık gelmektedir. Mimarinin özellikleri şöyledir:

- Mimaride  $3 \times 3$ 'lük evrişim matrisleri (conv  $3 \times 3$ ) ve  $1 \times 1$ 'lik evrişim matrisleri (conv  $1 \times 1$ ) kullanılmıştır. Evrişim matrisleri çoğunlukla imge özelliklerini ortaya çıkarmak için kullanılmaktadır.  $1 \times 1$ 'lik evrişim matrisi ise genellikle hesaplama hızını artırmak için kullanılmaktadır. Ağda evrişim işlemlerinden sonra ReLu aktivasyon fonksiyonu kullanılmaktadır.



Şekil 5. U-Net Mimarisi

- Biriktirme (pooling) katmanında  $2 \times 2$ 'lik en büyük değer biriktirmesi (max pool  $2 \times 2$ ) kullanılmıştır. Bu katman görüntüdeki bilgilerin olabildiğince kaybedilmeden görüntü boyutunun düşürülmesi için kullanılmaktadır.
- $2 \times 2$ 'lik yukarı biriktirme (up-conv  $2 \times 2$ ) küçültülen imgenin büyütülmesi için kullanılan bir işlemdir.

### 3.3. U-Net Mimarisinin Çalıştırılacağı Yazılımın Hazırlanması

U-Net mimarisinin ilk oluşturulan hali Şekil 5’te görülmektedir. Bu çalışmada orijinalinden farklı olarak  $572 \times 572$  yerine  $224 \times 224$  piksel boyutlarında veriler (girdiler) kullanılmıştır. Tüm veri setlerindeki imgeler  $224 \times 224$  olarak yeniden boyutlandırılmıştır ve eğitim yapılmıştır.

U-Net mimarisi için bir kod github.com websitesinde sunulmuştur [19]. Kod Wolfram Mathematica programlama dili için yazılmıştır. Bu kodlar değiştirilerek bu çalışmada kullanılmıştır.

#### 3.3.1. Ağ Eğitiminde Kullanılan Parametreler ve Optimizasyon

U-Net evrişimli sinir ağının eğitimi için öğrenme oranı sırasıyla 0.001, 0.002, 0.005, 0.008, 0.01, 0.012, 0.015 ve 0.1 seçilmiştir. Yapılan denemeler sonucunda en iyi sonuçların 0.001 öğrenme oranı ile gerçekleştiği tespit edilmiştir. Sonrasında 0.001 öğrenme oranı kullanılarak SGD, RMSProp ve Adam optimizasyon metotları için çeşitli testler yapılmıştır. SGD 100 devir (epoch) için hiçbir denemede yeterli öğrenmeyi sağlayamamıştır. RMSProp ve Adam kullanılabilir sonuçlar verse de Adam kullanılan ağ yapılarında eğitim ve test başarısı daha yüksek çıkmıştır. Bu tespit ile beraber tüm eğitim ve testler için Adam optimizasyon metodu kullanılmıştır. Adam optimizasyon metodundaki parametreler değiştirilmemiş olup standart olarak sunulan parametreler kullanılmıştır.

Çalışmada grup büyüklüğü (batch size) 10 seçilmiştir. Evrişimli sinir ağlarının eğitiminde grup büyüklüğü arttıkça daha yüksek eğitim ve test başarıları elde edildiği bilinmektedir. Teknik kısıtlar nedeniyle bu çalışmada grup büyüklüğü 10’den büyük seçilememiştir.

#### 3.4. Yapılan Eğitim ve Testler

Bu çalışmada eğitim ve test verisi için hem aynı hem de farklı veri setleri kullanılarak denemeler yapılmıştır. Yapılan farklı denemelerde kullanılan eğitim ve test verileri Tablo 1’de açıklanmıştır.

Tablo 1’de yanında herhangi bir oran bulunmayan hücreler tüm veri setinin kullanıldığını, oran bulunanlar ise veri setinin bir yüzdesinin kullanıldığını göstermektedir. Örneğin tablonun başlıktan sonraki ilk satırında ve birinci sütununda bulunan Özgenel (%80) ifadesi Özgenel veri setinin %80’inin eğitim için kullanıldığını, başlıktan sonraki ilk satırında ve ikinci sütununda bulunan Özgenel (%20) ifadesi eğitim için kullanılmamış olan %20’lik kısmın test için kullanıldığını ifade etmektedir. Başlıktan sonraki ikinci satırdaki Non-Crack ifadesi Non-Crack veri setinin tamamının eğitimde kullanıldığını göstermektedir.

**Tablo 1.** Yapılan Eğitim ve Testlerde Kullanılan Veri Setleri ve Veri Setlerindeki Verilerin Kullanım Yüzdesi


| Eğitimde Kullanılan Veri Setleri (Seti) | Testte Kullanılan Veri Setleri (Seti) |
|---|---------------------------------------|
| Özgenel (%80)                           | Özgenel (%20)                         |
| Non-Crack + Özgenel (%80)               | Özgenel (%20)                         |
| Rissbilder (%80)                        | Rissbilder (%20)                      |
| Non-Crack + Rissbilder (%80)            | Rissbilder (%20)                      |
| Volker (%80)                            | Volker (%20)                          |
| Non-Crack + Volker (%80)                | Volker (%20)                          |
| Non-Crack + Özgenel + Rissbilder        | Volker                                |
| Non-Crack + Özgenel + Volker            | Rissbilder                            |
| Non-Crack + Rissbilder + Volker         | Özgenel                               |

Tablo 1'deki eğitim ve testlerin tamamına yakını<sup>2</sup> sırası ile 5, 10, 15, 20, 25, 30, 40, 50 devir olacak şekilde yapılmıştır. (1 devir = 1 tam ileri besleme + 1 tam geri besleme)

#### 4. Uygulama ve Bulgular


Yapılan uygulamalarda Non-Crack veri setinin (içerisinde çatlak bulunmayan gürültülü fotoğraflardan oluşan veri seti) çatlak bulunan veri setleri içerisinde eğitime dahil edilmesi ile hem eğitim hem de test başarısının çok ciddi olarak arttığı bulunmuştur. Bu başarıyı göstermek için herhangi bir istatistiksel metrik kullanılmamıştır. Elde edilen sonuçlar rastgele seçilen<sup>3</sup> fotoğraflar ile açıklanmıştır. Gözle yapılan inceleme sonucu ile dahi başarı oranının artışı net bir şekilde görülebilmektedir.

Özgenel veri seti %80 eğitim %20 test olarak ayrıldıktan sonra yapılan denemede 5. devir sonucundaki test sonuçları Şekil 6'da görülmektedir. Aynı şekil eğitim veri seti içerisine Non-Crack veri setinin de eklenmesi ile oluşan sonuçların karşılaştırmasını içermektedir.




**Şekil 6.** 5 Devir Sonucunda Yapılan Testler a) Eğitimde sadece Özgenel Veri Setinin Kullanıldığı Durum b) Eğitim Verisi İçerisine Non-Crack Veri Setinin de Dâhil Edildiği Durum

Şekil 6'da görüldüğü üzere eğitim verisi içerisinde çatlak bulunmayan gürültülü resimlerin kullanılması başarıyı ciddi olarak artırmaktadır. Aynı durum diğer veri setleri için de değişmemiştir. Şekil 7 eğitim seti içerisinde sadece Rissbilder veri setinin kullanıldığı ve Rissbilder ile birlikte Non-Crack veri setinin de kullanıldığı durumlardaki test sonuçlarının bir kısmını göstermektedir. Şekil 8 ise eğitim seti içerisinde sadece Volker veri setinin kullanıldığı ve Volker ile birlikte Non-Crack veri setinin de kullanıldığı durumlardaki test sonuçlarının bir kısmını göstermektedir.



**Şekil 7.** 5 Devir Sonucunda Yapılan Testler a) Eğitimde sadece Rissbilder Veri Setinin Kullanıldığı Durum b) Eğitim Verisi İçerisine Non-Crack Veri Setinin de Dâhil Edildiği Durum



**Şekil 8.** 5 Devir Sonucunda Yapılan Testler a) Eğitimde sadece Volker Veri Setinin Kullanıldığı Durum b) Eğitim Verisi İçerisine Non-Crack Veri Setinin de Dahil Edildiği Durum

<sup>2</sup> Bazı eğitim ve testlerde belirli devir eğitimden sonra mimarinin aşırı öğrenmeye girdiği fark edilip daha yüksek devir sayısında eğitimler yapılmamış olup toplamda 54 farklı eğitim ve test yapılmıştır.

<sup>3</sup> Fotoğrafların rastgele seçimi için Wolfram Mathematica içerisinde bulunan "RandomChoice" fonksiyonu kullanılmıştır.




Elde edilen sonuçlar çalışmanın devamında eğitim verisi içerisinde Non-Crack veri setinin kullanılması gerektirdiğini sonucuna ulaştırmış ve en iyi test başarısının yakalanması için farklı devir sayılarında eğitimler yapılmıştır.


#### 4.1. Yapılan Testler

Bölüm 3.4'te belirtildiği üzere ağın eğitimi ve testi için farklı devir sayılarında denemeler yapılmıştır. Bu kısımda Tablo 1'de verilen, farklı veri setleri için yapılan denemelerden her bir farklı veri seti veya veri seti kombinasyonu için test başarısı en yüksek olanlar sunulacaktır. Bunun nedeni şöyle açıklanabilir: Bir evrişimli sinir ağı mimarisinin farklı öğrenme oranları, optimizasyon metotları ve devir sayıları kullanılarak en iyi test başarısının alınabildiği şekilde eğitildiğine emin olunduktan sonra tekrar eğitim yapmaya ihtiyaç duyulmamaktadır. Çünkü eğitim yapılmasında temel amaç en iyi başarıyı verecek ağ ağırlıklarının bulunmasıdır. Daha sonra aynı ağ mimarisi kullanılarak istenilen sayıda test yapılabilir.

Non-Crack veri setinin tamamının eğitim için kullanıldığı ve Özgenel veri setinin %80'inin eğitim %20'sinin test için kullanıldığı durumda en iyi sonuç 30 devirde bulunmuştur. Elde edilen ortalama eğitim doğruluk oranı (accuracy) 0.9924 çıkmıştır. Ortalama test doğruluk oranı ise 0.9641 bulunmuştur. Şekil 9 ve Şekil 10 sırasıyla eğitim ve test doğruluk oranlarını göstermektedir.




**Şekil 9.** Non-Crack + Özgenel (%80) Eğitim – Özgenel (%20) Veri Setleri ile Elde Edilen Eğitim Doğruluk Oranları



**Şekil 10.** Non-Crack + Özgenel (%80) Eğitim – Özgenel (%20) Veri Setleri ile Elde Edilen Test Doğruluk Oranları

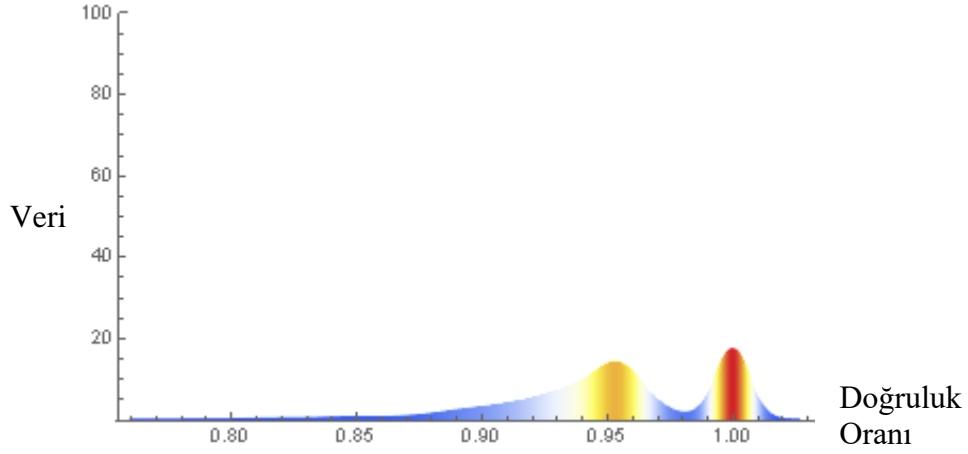
Şekil 9 ve Şekil 10’da verilen grafikler yoğunluk grafikleridir. Yoğunluk grafikleri histogram grafiklerinde çekirdek pürüzsüzlüğü (kernel smoother) ismi verilen bir tekniğin kullanılması ile elde edilmektedir. Bu grafik türünün histogram grafiğine göre avantajı dağılımın şeklini göstermekte daha başarılı olmasıdır. Şekil 9’da yatay eksen doğruluk oranını göstermektedir. Doğruluk oranı 0 ile 1 arasında değişen bir metriktir. Doğruluk oranı 1’e yaklaştıkça yapılan tahminlerin daha doğru olduğu anlaşılmalıdır. Düşey eksen veri sayısını göstermektedir. Şekil 9’da 1 doğruluk oranına denk gelen tepe, eğitim verisindeki bir kısım verinin doğruluk oranının 1 çıktığını göstermektedir. Bu veriler, içerisinde çatlak fotoğrafı bulunmayan verilerdir. Şekilde 1’den büyük doğruluk değerleri de okunmaktadır. Bunun nedeni çizilen grafiğin kuyruklarının yatay eksene asimptot olduğu yani kuyrukların x eksenini sonsuzda kestiği varsayımındandır. Yoğunluk veya dağılım grafiklerinde bu durum gözlenebilmektedir. Burada tepe nokta baz alınarak doğruluk oranının 1 olduğu çıkarımı yapılmalıdır. 0.97’deki tepe ise içerisinde çatlak bulunan verilerin çok büyük bir kısmının 0.97 doğruluk oranı etrafında yoğunlaştığını belirtmektedir.

Şekil 11 yapılan testlerden bir kısım örnek sunmaktadır. Eğitilen U-Net mimarisinin çok küçük çatlakları bulamadığı görülmüştür. Bunun sebebinin eğitim için kullanılan veri seti boyutlarının teknik yetersizlik sebebi ile  $224 \times 224$  piksel boyutlarına küçültülmesi olduğu düşünülmektedir. Boyutlar küçüldükçe imge içerisinde bilgi kaybı olabilmektedir. Daha yüksek boyutlardaki giriş verileri ile eğitim yapıldığında çok küçük çatlakların da bulunabileceği öngörülmektedir.




**Şekil 11.** Non-Crack + Özgenel (%80) Verileri ile Eğitilmiş U-Net Mimarisinin Test Sonuçları  
a) Orijinal Veri b) Orijinal Verinin Maskelenmiş Hali c) Bu Çalışmada Bulunan Sonuç

Non-Crack veri setinin tamamının eğitim için kullanıldığı ve Rissbilder veri setinin %80’inin eğitim %20’sinin test için kullanıldığı durumda en iyi sonuç 15 devirde bulunmuştur. Elde edilen ortalama eğitim doğruluk oranı 0.9537 çıkmıştır. Ortalama test doğruluk oranı ise 0.9407 bulunmuştur. Şekil 12 ve Şekil 13 sırasıyla eğitim ve test doğruluk oranlarını göstermektedir. Şekil 14 yapılan testlerden bir kısım örnek sunmaktadır.




**Şekil 12.** Non-Crack + Rissbilder (%80) Eğitim – Rissbilder (%20) Veri Setleri ile Elde Edilen Eğitim Doğruluk Oranları


Non-Crack veri setinin tamamının eğitim için kullanıldığı ve Volker veri setinin %80'inin eğitim %20'sinin test için kullanıldığı durumda en iyi sonuç 15 devirde bulunmuştur. Elde edilen ortalama eğitim doğruluk oranı 0.9735 çıkmıştır. Ortalama test doğruluk oranı ise 0.9279 bulunmuştur. Şekil 15 ve Şekil 16 sırasıyla eğitim ve test doğruluk oranlarını göstermektedir.




**Şekil 13.** Non-Crack + Rissbilder (%80) Eğitim – Rissbilder (%20) Veri Setleri ile Elde Edilen Test Doğruluk Oranları



**Şekil 14.** Non-Crack + Rissbilder (%80) Verileri ile Eğitilmiş U-Net Mimarisinin Test Sonuçları  
a) Orijinal Veri b) Orijinal Verinin Maskelenmiş Hali c) Bu Çalışmada Bulunan Sonuç




**Şekil 15.** Non-Crack + Volker (%80) Eğitim – Volker (%20) Veri Setleri ile Elde Edilen Eğitim Doğruluk Oranları



**Şekil 16.** Non-Crack + Volker (%80) Eğitim – Volker (%20) Veri Setleri ile Elde Edilen Test Doğruluk Oranları

Şekil 17 yapılan testlerden bir kısım örnek sunmaktadır.




**Şekil 17.** Non-Crack + Volker (%80) Verileri ile Eğitilmiş U-Net Mimarisinin Test Sonuçları  
a) Orijinal Veri b) Orijinal Verinin Maskelenmiş Hali c) Bu Çalışmada Bulunan Sonuç


Eğitimde ve testte Volker veri setinin kullanılması sonucu fotoğraflardaki bazı çatlakların bulunamadığı tespit edilmiştir. Bunun nedenlerinin şunlar olduğu düşünülmektedir:

- Volker veri setindeki fotoğraflar ile maskelenmiş görüntüler tamamen eşleşmemektedir. Veri setindeki fotoğraflarda çatlak bulunmayan kimi kısımlar çatlak varmış gibi etiketlenmiştir. Bunun öğrenmeyi zorlaştırdığı düşünülmektedir.
- Veri setindeki fotoğraflar zaman zaman oldukça bulanıktır. Bu gerçek dünya problemlerinin test edilmesi için bir fırsat sunmaktadır fakat teknik yetersizliklerden kaynaklı olarak eğitim için görüntülerin  $224 \times 224$  piksel boyutlarına küçültülmek zorunda kalınması, hali hazırda bulanık olan görüntülerdeki bilgilerin fazlaca azalmış olduğunu düşündürmektedir. Bu düşünceyi doğrulamak ya da yanlışlamak için daha güçlü bilgisayarlar ile testler yapılmalıdır.


Eğitimde Non-Crack, Özgenel ve Rissbilder veri setlerinin kullanıldığı ve test için Volker veri setinin kullanıldığı durumda en iyi sonuç 20 devirde bulunmuştur. Elde edilen ortalama eğitim doğruluk oranı 0.9533 çıkmıştır. Ortalama test doğruluk oranı ise 0.9294 bulunmuştur. Şekil 18 ve Şekil 19 sırasıyla eğitim ve test doğruluk oranlarını göstermektedir.




Şekil 18. Non-Crack + Özgenel + Rissbilder Veri Setleri ile Elde Edilen Eğitim Doğruluk Oranları



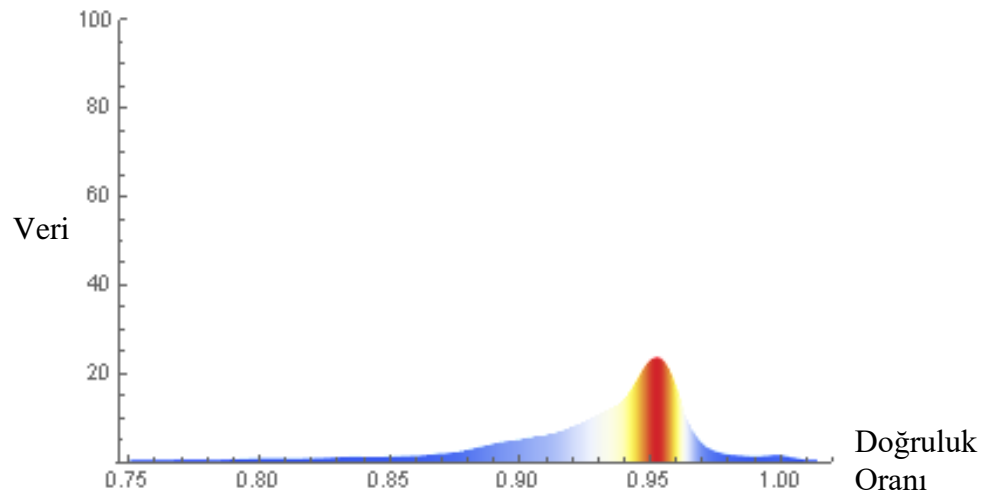
Şekil 19. Non-Crack + Özgenel + Rissbilder Veri Setleri ile Eğitim, Volker Veri Seti ile Test Yapıldığında Test Doğruluk Oranları




**Şekil 20.** Non-Crack + Özgenel + Rissbilder Verileri ile Eğitilmiş Volker Veri Seti ile Test Edilmiş U-Net Mimarisinin Test Sonuçları a) Orijinal Veri b) Orijinal Verinin Maskelenmiş Hali c) Bu Çalışmada Bulunan Sonuç



**Şekil 21.** Non-Crack + Özgenel + Volker Veri Setleri ile Elde Edilen Eğitim Doğruluk Oranları




**Şekil 22.** Non-Crack + Özgenel + Volker Veri Setleri ile Eğitim, Rissbilder Veri Seti ile Test Yapıldığında Test Doğruluk Oranları

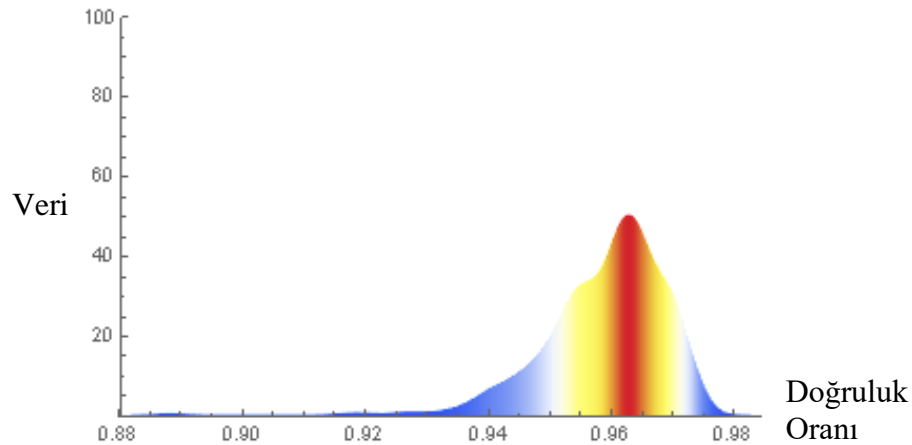


**Şekil 23.** Non-Crack + Özgenel + Volker Verileri ile Eğitilmiş Rissbilder Veri Seti ile Test Edilmiş U-Net Mimarisinin Test Sonuçları a) Orijinal Veri b) Orijinal Verinin Maskelenmiş Hali c) Bu Çalışmada Bulunan Sonuç


Şekil 20 yapılan testlerden bir kısım örnek sunmaktadır. Eğitimde Non-Crack, Özgenel ve Volker veri setlerinin kullanıldığı ve test için Rissbilder veri setinin kullanıldığı durumda en iyi sonuç 20 devirde bulunmuştur. Elde edilen ortalama eğitim doğruluk oranı 0.9686 çıkmıştır. Ortalama test doğruluk oranı ise 0.9329 bulunmuştur. Şekil 21 ve Şekil 22 sırasıyla eğitim ve test doğruluk oranlarını göstermektedir. Şekil 23 yapılan testlerden bir kısım örnek sunmaktadır.



**Şekil 24.** Non-Crack + Rissbilder + Volker Veri Setleri ile Elde Edilen Eğitim Doğruluk Oranları



**Şekil 25.** Non-Crack + Rissbilder + Volker Veri Setleri ile Eğitim, Özgenel Veri Seti ile Test Yapıldığında Test Doğruluk Oranları



**Şekil 26.** Non-Crack + Rissbilder + Volker Verileri ile Eğitilmiş Özgenel Veri Seti ile Test Edilmiş U-Net Mimarisinin Test Sonuçları a) Orijinal Veri b) Orijinal Verinin Maskelenmiş Hali c) Bu Çalışmada Bulunan Sonuç

Eğitimde Non-Crack, Rissbilder ve Volker veri setlerinin kullanıldığı ve test için Özgenel veri setinin kullanıldığı durumda en iyi sonuç 20 devirde bulunmuştur.

Eğitimde Non-Crack, Rissbilder ve Volker veri setlerinin kullanıldığı ve test için Özgenel veri setinin kullanıldığı durumda elde edilen ortalama eğitim doğruluk oranı 0.9490 çıkmıştır. Ortalama test doğruluk oranı ise 0.9600 bulunmuştur. Şekil 24 ve Şekil 25 sırasıyla eğitim ve test doğruluk oranlarını göstermektedir. Şekil 26 yapılan testlerden bir kısım örnek sunmaktadır.

## 5. Sonuçlar

Farklı veri setleri ile yapılan farklı denemeler sonucunda elde edilen bulgulara göre U-Net mimarisinin yapısal çatlakların tespitinde oldukça güçlü ve kullanışlı bir araç olduğu sonucuna ulaşılmıştır. Elde edilen diğer sonuçlar şunlardır:

- Yapısal çatlakların tespitinde kullanılacak eğitim verisi içerisinde yapıların farklı bölgelerine ait içerisinde çatlak içermeyen gürültülü fotoğrafların eklenmesi ile eğitim ve test başarısının ciddi oranda arttığı gözlenmiştir.
- Test örneklerine bakıldığında Volker veri seti haricindeki diğer veri setlerinde fotoğraflardaki çatlakların tamamının tespit edildiği fark edilmiştir. Bazı test verilerinde görüntüdeki çatlığa ait kısmın tamamı piksel bazında işaretlenememiştir fakat çatlığın büyük bir kısmının işaretlenmiş olmasının, eğitilen U-Net mimarisinin görüntüdeki çatlığı bulduğunu göstermektedir.
- Doğru etiketlenmiş veri setlerinin yüksek çözünürlüklü olarak eğitilmesi ile gerçek dünyadaki yapısal çatlakların tespitinde U-Net mimarisinin kullanılabilmesi düşünülmektedir.
- Eğitilmiş evrişimli sinir ağı mimarileri ile insansız hava araçlarının birleştirilmesi ile çatlak tespitinin etkili bir şekilde yapılabileceği düşünülmektedir.

Kurumların ve kuruluşların teknolojik işsizliğe yol açmayacak şekilde yapısal yüzey kusurlarının tespiti için yapay zekâ ve otomasyondan yararlanması gerektiği düşünülmektedir.



## 6. Gelecekteki Çalışmalar

- Bu çalışmada teknik imkânlar sebebi ile sinir ağı eğitiminde kullanılan veriler  $224 \times 224$  boyutlarına küçültülmüştür. Daha büyük boyutlarda girdiler ile hem eğitim hem de test başarısının artması mümkündür. Ayrıca yine teknik kısıtlar nedeni ile grup büyüklüğü (batch size) bu çalışmada 10 seçilmiştir. Aynı şekilde grup büyüklüğünün daha yüksek olması ile eğitim ve test başarısının artacağı öngörülmektedir.
- Kullanılan veri setlerindeki imgelerin çeşitli görüntü işleme teknikleri ile (döndürme, kırpmaya vb.) işlenmesi mümkündür. İşlenmiş verilerin evrişimli sinir ağında kullanılması ile başarı oranının artacağı öngörülmektedir.
- U-Net mimarisi dışındaki evrişimli sinir ağı görüntü bölütleme mimarilerinin yapısal çatlak tespiti için kullanılabilirliğinin araştırılmasının faydalı olacağı düşünülmektedir.
- Bu çalışmada başarı oranını ölçebilmek için yoğunluk grafiği, doğruluk oranı ve rastgele seçilen test imgeleri kullanılmıştır. Gelecek çalışmalarda bu metriklerin yanı sıra kesinlik (precision), duyarlılık (recall), mIoU, F1 puanı (F1 score), ROC vb. metrikler kullanılabilir.
- Kapsül Ağları (CapsuleNet) literatürde evrişimli sinir ağlarına bir alternatif olarak sunulmuştur. Bu ağların otonom çatlak tespitinde kullanılabilirliğinin araştırılması gerektiği düşünülmektedir.
- Çalışmanın gelecekte tüm yüzey kusurlarının tespit edileceği şekilde genişletilmesi ve insansız hava aracı ile birleştirilmesi gerektiği düşünülmektedir.

## Yazar(lar)ın Katkıları

TK çalışmaları yapmış ve makalenin yazımını gerçekleştirmiştir. Yazar makalenin son halini okudu ve onayladı.

## Çıkar Çatışması

Yazar(lar), çıkar çatışması olmadığını beyan eder.

## Kaynaklar

- [1] Karaçay, T., Özbaşaran, H., “Yapı Mühendisliğinde Yapay Zekâ: Geçmişten Günümüze Türkçe Çalışmalar”, *Mühendislik Bilimlerinde Yeni Yaklaşımlar*, Lıvre De Lyon, Lyon, France, 2021.
- [2] Yang, C.-H., Wen, M.-C., Chen, Y.-C., Kang, S.-C., “An Optimized Unmanned Aerial System for Bridge Inspection”, 32nd International Symposium on Automation and Robotics in Construction and Mining: Connected to the Future, Proceedings, Oulu, Finland, 1-6, 2015.
- [3] Qiao, W., Ma, B., Liu, Q., Wu, X., Li, G., “Computer Vision-Based Bridge Damage Detection Using Deep Convolutional Networks with Expectation Maximum Attention Module”, *Sensors*, 2021, 21(3): 824-840.
- [4] Liu, Z., Cao, Y., Wang, Y., Wang, W., “Computer vision-based concrete crack detection using U-net fully convolutional networks”, *Automation in Construction*, 2019, 104: 129–139.
- [5] Cha, Y. J., Choi, W., Büyüköztürk, O., “Deep Learning-Based Crack Damage Detection Using Convolutional Neural Networks”, *Computer-Aided Civil and Infrastructure Engineering*, 2017, 32(5): 361–378.
- [6] Modarres, C., Astorga, N., Droguett, E. L., Meruane, V., “Convolutional neural networks for automated damage recognition and damage type identification”, *Structural Control Health Monitoring*, 2018, 25(10): 1–17.
- [7] Dorafshan, S., Thomas, R. J., Maguire, M., “Comparison of deep convolutional neural

- networks and edge detectors for image-based crack detection in concrete”, *Construction and Building Materials*, 2018, 186: 1031–1045.
- [8] Özgenel, Ç. F., Sorguç, A. G., “Performance Comparison of Pretrained Convolutional Neural Networks on Crack Detection in Buildings”, *ISARC 2018 - 35th International Symposium on Automation and Robotics in Construction and International AEC/FM Hackathon: The Future of Building Things*, Oulu, Finland, 693-700, 2018.
- [9] Özgenel, Ç. F., “Concrete Crack Images for Classification”, <https://data.mendeley.com/datasets/5y9wdsg2zt/2> (Son Erişim: 21.06.2021).
- [10] Wang, N., Zhao, Q., Li, S., Zhao, X., Zhao, P., “Damage Classification for Masonry Historic Structures Using Convolutional Neural Networks Based on Still Images”, *Computer-Aided Civil and Infrastructure Engineering*, 2018, 33(12): 1073–1089.
- [11] Li, S., Zhao, X., “Image-Based Concrete Crack Detection Using Convolutional Neural Network and Exhaustive Search Technique”, *Advances in Civil Engineering*, 2019, 2019: 1-12
- [12] Dung, C. V., Anh, L. D., “Autonomous concrete crack detection using deep fully convolutional neural network”, *Automation in Construction*, 2019, 99: 52–58.
- [13] Li, S., Zhao, X., Zhou, G., “Automatic pixel-level multiple damage detection of concrete structure using fully convolutional network”, *Computer-Aided Civil and Infrastructure Engineering*, 2019, 34(7): 616–634.
- [14] Ren, Y., Huang, J., Hong, Z., Lu, W., Yin, J., Zou, L., Shen, Z., “Image-based concrete crack detection in tunnels using deep fully convolutional networks”, *Construction and Building Materials*, 2020, 234.
- [15] Li, B., Wang, K. C. P., Zhang, A., Yang, E., Wang, G., “Automatic classification of pavement crack using deep convolutional neural network”, *International Journal of Pavement Engineering*, 2020, 21(4): 457–463.
- [16] Özgenel, Ç. F., “Concrete Crack Segmentation Dataset”, <https://data.mendeley.com/datasets/jwsn7tfbrp/1> (Son Erişim: 21.06.2021).
- [17] Middha, L., “Crack Segmentation Dataset Over 11,000 images with masks”, <https://www.kaggle.com/lakshaymiddha/crack-segmentation-dataset> (Son Erişim: 21.06.2021).
- [18] Ronneberger, O., Fischer, P., Brox, T., “U-Net: Convolutional Networks for Biomedical Image Segmentation”, *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, Munich, Germany, 234–241, 2015.
- [19] Hashmi, A., Golyshev, A., “UNet-Segmentation-Wolfram”, <https://github.com/alihashmiii/UNet-Segmentation-Wolfram> (Son Erişim: 21.06.2021).
- [20] Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A. C., Fei-Fei, L., “ImageNet Large Scale Visual Recognition Challenge”, *International Journal of Computer Vision*, 2015, 115(3): 211–252.
- [21] He, K., Zhang, X., Ren, S., Sun, J., “Deep Residual Learning for Image Recognition”, *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, USA, 770–778, 2016.